

直交射影層を用いた畳み込みニューラルネットワークによる画像超解像

馬場 敦之[†] 片岡 秀公[†] 北原 大地[†] 平林 晃[†]

[†] 立命館大学情報理工学部 〒525-8577 滋賀県草津市野路東 1-1-1

E-mail: [†] d-kita@fc.ritsumei.ac.jp, akirahrb@media.ritsumei.ac.jp

あらまし 畳み込みニューラルネットワーク (CNN) を用いた超解像手法において, ネットワークの学習に用いる評価関数に観測誤差を導入し, 学習後のネットワークが生成した超解像画像に直交射影を適用する手法を提案する. 従来法では白飛びや黒飛びなどのアーティファクトが生成されることがあった. この問題を解決するために提案法では, 学習に用いる評価関数に観測誤差を導入して, 学習データに対する観測整合性を保証する. しかし, これだけでは新規のテストデータに対する観測整合性は保証されない. そこで提案法はさらに, ネットワークが生成した超解像画像を観測誤差が 0 になる線形多様体に直交射影する. これにより提案法は, アーティファクトを生成することなく, 高品質の画像を生成する. 計算機シミュレーションにより, 提案法の有効性を示す.

キーワード 画像超解像, 畳み込みニューラルネットワーク, 直交射影層

Image Super-Resolution via Convolutional Neural Network Using an Orthogonal Projection Layer

Nobuyuki BABA[†], Hidetomo KATAOKA[†], Daichi KITAHARA[†], and Akira HIRABAYASHI[†]

[†] College of Information Science and Engineering, Ritsumeikan University
1-1-1 Nojihigashi, Kusatsu, Shiga, 525-8577 Japan

Abstract We propose a super-resolution method using a convolutional neural network (CNN) that reduces observation error during training and exploits an orthogonal projection layer after training. A conventional super-resolution method using CNN suffers from black or white pixel wise artifacts. To solve this problem, we add an observation error to the cost function for training. This guarantees consistency for training examples, but not for a novel input data after training. Hence, we further introduce the orthogonal projection onto a linear manifold, in which the observation error is completely zero. These two ideas enable us to produce high quality super-resolution results without the artifact. Simulation results show the effectiveness of the proposed method.

Key words Image Super-Resolution, Convolutional Neural Network, Orthogonal Projection Layer

1. はじめに

画像超解像とは, 画素数の少ない画像 (低解像度画像) から高周波成分が復元された画素数の多い画像 (高解像度画像) を生成する技術である [1]. 例えば, 犯罪捜査においては, 防犯カメラなどに写った人物や車の拡大が求められることがある [2]. 他にも, 生物学分野においては, 顕微鏡画像に対して超解像を行い, 従来の約 10 倍の拡大率で高精細な画像を生成することに成功している [3]. いずれの分野においても画像超解像では, 単に画素数を増やすだけではなく, 高周波成分が復元された鮮明な画像を生成することが求められる.

単一画像のみからの超解像は, 解が一意に定まらない劣決定逆問題である. 画素数を増やす簡単な方法として, 最近傍補間,

双線形補間, 双三次補間などの代数的補間法を用いることが考えられる [4]. これらの手法は非常に高速ではあるが, 最近傍補間と双線形補間では高周波成分が全く復元されず, 双三次補間でも高周波成分が十分に復元されないため, 超解像結果 (超解像画像と呼ぶ) が鮮明でないという問題がある.

低解像度画像から失われた高周波成分を精度よく復元するために, 大量の低解像度画像と高解像度画像の組からなる学習データを利用する手法が提案されている [5]–[9]. Yang らは, 学習データを用いて辞書学習を行う超解像手法を提案した [5]. 更に, Elad より, この手法における辞書学習アルゴリズムの改良も提案されている [6]. これらの手法では, 代数的補間法に比べて鮮明な超解像画像が得られるが, 辞書学習と画像生成にかかる時間がどちらも長いという欠点がある.



(a) 超解像画像 (b) aの低解像度画像 (c) 入力画像
図1 SRCNNによる超解像画像を再度ダウンサンプリングした結果

Dongらは、畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) を用いた超解像手法 SRCNN を提案した [7]。この手法では、低解像度画像を入力、高解像度画像を出力とする CNN を学習する。画像生成時には、学習した CNN に低解像度画像を入力するだけで、超解像画像が瞬時に出力される。SRCNN は入力層において双三次補間を行うが、これを削除して CNN の学習時間を短縮する Fast SRCNN [8] や、出力層に sub-pixel 畳み込み層を追加した手法 [9] も提案されている。CNN による画像超解像は、辞書学習を用いた手法 [5], [6] よりも優れた性能を示しており、画像生成にかかる時間も非常に短いため、近年大きな注目を集めている。

CNN を用いた超解像手法の問題点として、出力超解像画像と入力低解像度画像の間の整合性が、必ずしも保証されないことが挙げられる。図1に示すように、実際に SRCNN による超解像画像 (図1(a)) を再度ダウンサンプリングすると、得られる低解像度画像 (図1(b)) は入力低解像度画像 (図1(c)) と異なっていることが確認できる。このように、従来手法は超解像画像のダウンサンプリング結果を考慮しておらず、入力低解像度画像の情報を活用しきれていない。したがって、入力画像には存在しない不自然な白飛びや黒飛びが発生してしまうこともある。

この問題を解決するために、本研究では CNN の出力層 (最終層) に新たに直交射影層を追加することを提案する。提案法では、ダウンサンプリング結果が入力低解像度画像と一致する超解像画像全体の集合を考える。この集合は線形多様体であり、直交射影の計算も容易である。提案法では、出力層で直交射影を適用することで、入力低解像度画像との整合性が保証された超解像画像を生成することができる。更には、CNN の学習で用いる損失関数にも、「高解像度画像と超解像画像の誤差」の他に、「線形多様体上の誤差」及び「低解像度画像と超解像画像のダウンサンプリング結果の誤差」を考慮したものをを用いることを提案する。数値実験により、提案法は、従来発生した白飛びや黒飛びが除去された高品質な画像を生成できることを示す。

2. CNN を用いた超解像手法

2.1 ダウンサンプリングの定式化

超解像を行う低解像度画像を Y で表す。低解像度画像 Y の縦方向の画素数を I 、横方向の画素数を J とし、画素値を $Y_{i,j}$ ($i = 1, 2, \dots, I; j = 1, 2, \dots, J$) とする。本研究では、低解像度画像 Y は、縦方向の画素数が IK 、横方向の画素数が JL の高解像度画像 X をダウンサンプリングすることで得られるものとする。また、ダウンサンプリングは重み付き平均でモデル化

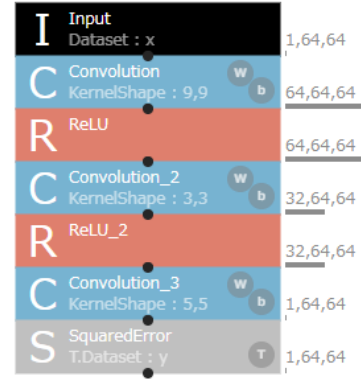


図2 SRCNN のネットワークモデル (超解像画像の画素数: 64×64 , フィルタサイズ: 9×9 (第1層), 3×3 (第2層), 5×5 (第3層))

されるものとする。具体的には、高解像度画像 X の画素値を $X_{i,j}$ ($i = 1, 2, \dots, IK; j = 1, 2, \dots, JL$) とし、重みを $w_{k,l} > 0$ ($k = 1, 2, \dots, K; l = 1, 2, \dots, L$) とすれば、低解像度画像は

$$Y_{i,j} = \sum_{k=1}^K \sum_{l=1}^L w_{k,l} X_{(i-1)K+k, (j-1)L+l} \quad (1)$$

のように与えられる。ここで、重み $w_{k,l}$ は $\sum_{k=1}^K \sum_{l=1}^L w_{k,l} = 1$ を満たしている。低解像度画像 Y と高解像度画像 X をベクトル化したものを、それぞれ $\mathbf{y} \in \mathbb{R}^{IJ}$, $\mathbf{x} \in \mathbb{R}^{IJKL}$ とすれば、適当な行列 $A \in \mathbb{R}^{IJ \times IJKL}$ を用いて、式 (1) は

$$\mathbf{y} = A\mathbf{x} \quad (2)$$

と表される。

2.2 SRCNN

Dongらは、CNN による単一画像からの超解像手法を提案した [7]。この手法は SRCNN と呼ばれ、低解像度画像 Y から高解像度画像 X への写像 $F: \mathbb{R}^{IJ} \rightarrow \mathbb{R}^{IJKL}$ を直接学習するため、新規の低解像度画像をネットワークに入力すれば、畳み込み演算により瞬時に超解像画像が生成される。SRCNN のネットワークモデルを図2に示す。畳み込み層は全部で3つあり、それぞれの層では、特徴抽出、非線形マッピング、画像生成を行うと解釈できる。第1層で、 Y の特徴はパッチごとに

$$F_1 = \max(0, W_1 * \tilde{Y} + B_1)$$

と計算される。ここで、 \tilde{Y} は入力低解像度画像 Y を双三次補間して得られる画像であり、画素数は高解像度画像 X の画素数と一致している。 W_1 は第1層における畳み込みフィルタ、 B_1 は第1層におけるバイアス、 $*$ は畳み込み演算子を表している。 $\max(0, x)$ は、負の値を0にし、正の値を保持する活性化関数であり、Rectified Linear Unit (ReLU) と呼ばれる。第2層の非線形マッピングでは、第1層の出力 F_1 を入力として

$$F_2 = \max(0, W_2 * F_1 + B_2)$$

が計算される。第3層の出力層では ReLU を使用せず、

$$\hat{X} = W_3 * F_2 + B_3$$

のように計算することで、超解像画像 \hat{X} が出力される。



(a) 目標画像 (b) $\beta = 0.01$ (c) $\beta = 0.25$

図3 損失関数に式(4)を用いて学習したCNNによる超解像結果

3. 直交射影層を導入したCNNによる超解像

3.1 超解像画像の再ダウンサンプリング結果の考慮

CNNの学習には、複数の低解像度画像と高解像度画像の組 $\{Y_n, X_n\}_{n=1}^N$ を用いる。低解像度画像 Y_n を入力としたときのCNNの出力超解像画像を \hat{x}_n とする。また、低解像度画像、高解像度画像、超解像画像をベクトル化したものを、それぞれ y_n, x_n, \hat{x}_n と定義する。SRCNN [7] では、CNNのパラメータ $\Theta = \{W_i, B_i\}_{i=1}^3$ を学習する際に用いる損失関数は、

$$L(\Theta) = \frac{1}{N} \sum_{n=1}^N \|\hat{x}_n - x_n\|^2 \quad (3)$$

である。式(3)は、「高解像度画像 x_n と出力超解像画像 \hat{x}_n の平均二乗誤差」を表しており、文献 [8], [9] においても、式(3)が損失関数として使われている。CNNの学習とは、損失関数の値を小さくするようにパラメータ Θ を更新していくことである。

従来手法 [7]–[9] では、CNNの学習時に、高解像度画像 x_n と出力結果 \hat{x}_n の誤差のみを評価している。したがって、超解像画像 \hat{x}_n を再度ダウンサンプリングして得られる画像 $A\hat{x}_n$ が、元の入力低解像度画像 y_n に近いかどうかは考慮していない。一方で、真の高解像度画像 x_n ($n = 1, 2, \dots, N$) に関しては、式(2)より $Ax_n = y_n$ が常に成立することから、学習データの情報を十分に活用するためには、超解像画像のダウンサンプリング結果を考慮する必要がある。

そこで、式(3)に、「低解像度画像 y_n と超解像画像のダウンサンプリング結果 $A\hat{x}_n$ の平均二乗誤差」を加えた値を小さくするように学習を行う超解像手法を考える。学習に用いる損失関数は、 $\beta > 0$ を用いて

$$L(\Theta) = \frac{1}{N} \sum_{n=1}^N \|\hat{x}_n - x_n\|^2 + \frac{\beta}{N} \sum_{n=1}^N \|A\hat{x}_n - y_n\|^2 \quad (4)$$

のように定義される。図3は、式(4)の損失関数を用いて学習したCNNによる超解像結果を示している。 $\beta = 0.01$ のときの結果(図3(b))を見ると、従来手法($\beta = 0$ のとき)の結果(図1(a))に比べて、白飛びや黒飛びが多少減りはするものの、依然として目標画像(図3(a))と大きく異なる箇所が存在している。一方で、 $\beta = 0.25$ のときの結果(図3(c))は、従来手法の結果に比べて、白飛びや黒飛びはほぼ除去されるが、画素値が全体的に低くなっており(画像全体が暗くなっており)、推定精度は劣化してしまう。また、式(4)の損失関数を用いた場合にも、条件 $A\hat{x}_n = y_n$ を完全に満たすことは不可能である。




図4 提案手法で用いる線形多様体 \mathcal{A}_n とその空間内で算出する誤差

3.2 入力低解像度画像との整合性が保証された超解像手法

本研究では、出力超解像画像 \check{x}_n が $A\check{x}_n = y_n$ を常に満たすような超解像手法を提案する。ダウンサンプリング結果が入力低解像度画像 y_n と一致する超解像画像の集合

$$\begin{aligned} \mathcal{A}_n &:= \{x \in \mathbb{R}^{IJKL} \mid Ax = y_n\} \\ &= x_n + \text{Null}(A) := \{x_n + z \in \mathbb{R}^{IJKL} \mid Az = \mathbf{0}\} \quad (5) \end{aligned}$$

を定義すると、 $x_n \in \mathcal{A}_n$ であり、式(5)から \mathcal{A}_n は線形多様体になる。ここで、閉部分空間 $\text{Null}(A)$ ($\subset \mathbb{R}^{IJKL}$) は A の零空間である。本研究では、 \mathcal{A}_n への直交射影 $P_{\mathcal{A}_n}: \mathbb{R}^{IJKL} \rightarrow \mathcal{A}_n$ を従来のCNNの出力結果 \hat{x}_n に適用することで、入力低解像度画像 y_n との整合性が保証された超解像画像 $\check{x}_n := P_{\mathcal{A}_n}(\hat{x}_n)$ を生成する手法を提案する。提案する超解像画像 \check{x}_n は具体的に、

$$\begin{aligned} \check{x}_n &= P_{\mathcal{A}_n}(\hat{x}_n) = \operatorname{argmin}_{x \in \mathcal{A}_n} \|\hat{x}_n - x\| \\ &= \hat{x}_n - A^T(AA^T)^{-1}(A\hat{x}_n - y_n) \\ &= \hat{x}_n - \frac{1}{\sum_{k=1}^K \sum_{l=1}^L w_{k,l}^2} A^T(A\hat{x}_n - y_n) \end{aligned}$$

のように与えられる。

式(3)の「高解像度画像 x_n と従来の出力結果 \hat{x}_n の二乗誤差」は、図4で示したように、「 \mathcal{A}_n に垂直な成分の二乗誤差」と「 \mathcal{A}_n に平行な成分の二乗誤差」に分解できるため、

$$\begin{aligned} \|\hat{x}_n - x_n\|^2 &= \|\hat{x}_n - P_{\mathcal{A}_n}(\hat{x}_n)\|^2 + \|P_{\mathcal{A}_n}(\hat{x}_n) - x_n\|^2 \quad (6) \\ &\geq \|P_{\mathcal{A}_n}(\hat{x}_n) - x_n\|^2 = \|\check{x}_n - x_n\|^2 \quad (7) \end{aligned}$$

が成立する。式(7)からも分かるように、 $A\hat{x}_n \neq y_n$ であれば、直交射影を適用することで、高解像度画像 x_n との二乗誤差が必ず小さくなる。また、式(3)や式(4)の損失関数では、上記垂直成分の誤差と平行成分の誤差を、式(6)のように1:1の比率で評価していた。しかしながら、垂直成分の誤差は直交射影により0にできるため、平行成分の誤差のほうがより重要である。そこで本研究では、可変パラメータ $\alpha \in [1, 2]$ を用いて、垂直成分の誤差と平行成分の誤差を $2 - \alpha : \alpha$ という比率で評価することを提案する。結果として、提案手法において、

CNN の学習に用いる損失関数は

$$L(\Theta) = \frac{2-\alpha}{N} \sum_{n=1}^N \|\hat{x}_n - P_{A_n}(\hat{x}_n)\|^2 + \frac{\alpha}{N} \sum_{n=1}^N \|P_{A_n}(\hat{x}_n) - x_n\|^2 + \frac{\beta}{N} \sum_{n=1}^N \|A\hat{x}_n - y_n\|^2 \quad (8)$$

のようになる．式 (8) の損失関数 L は微分可能であるため，通常のニューラルネットワークの学習と同様に，勾配を基にパラメータ Θ の更新を行う．例えば，Kingma らが提案した adaptive moment estimation (ADAM) アルゴリズム [10] は，

$$\begin{cases} m_t = \gamma_1 m_{t-1} + (1 - \gamma_1) \frac{\partial L}{\partial \theta}(\theta_{t-1}) \\ v_t = \gamma_2 v_{t-1} + (1 - \gamma_2) \left| \frac{\partial L}{\partial \theta}(\theta_{t-1}) \right|^2 \\ \hat{m}_t = \frac{m_t}{1 - \gamma_1^t} \\ \hat{v}_t = \frac{v_t}{1 - \gamma_2^t} \\ \theta_t = \theta_{t-1} - \mu \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \end{cases}$$

のようにパラメータの更新を行う．ここで， $m_0 = v_0 = 0$ ， $\gamma_1 = 0.9$ ， $\gamma_2 = 0.999$ ， $\mu = 0.001$ ， $\epsilon = 10^{-8}$ であり， θ は全パラメータ $\Theta = \{W_l, B_l\}_{l=1}^3$ の中の，ある 1 つの成分を表す．

4. 数値実験

4.1 実験概要

ImageNet^(注1) から 3,286 枚の自然画像データセットを用いて CNN の学習を行う．学習データの高解像度画像として，データセット内の画像を双三次補間でサイズ 64×64 に縮小し，更にグレースケールに変換したものを用いる．式 (1) において， $K = L = 2$ ， $w_{k,l} = 1/4$ ($k, l = 1, 2$) として高解像度画像をダウンサンプリングすることで，サイズ 32×32 の学習用の低解像度画像を用意する．テスト画像には，超解像性能の比較によく用いられる Set5 [11] (baby, bird, butterfly, head, woman) を利用する．テスト画像は，学習データと同様に，高解像度画像のサイズを 64×64 ，低解像度画像のサイズを 32×32 として，従来手法 (SRCNN) と提案手法 (SRCNN の出力層に直交射影層を追加したもの) による超解像結果を比較する．シミュレーションを行う実験環境は表 1 の通りである．

4.2 式 (8) における寄与率の選定と実験結果

提案手法では，式 (8) における 3 つの項の寄与率 $2 - \alpha : \alpha : \beta$ を設定する必要がある．寄与率の設定により画像精度や白飛び・黒飛びの有無が大きく変化するため，適切な寄与率の選定を行う．適切かどうかの判定には，baby の超解像結果を用いた．

まず寄与率 $2 - \alpha : \alpha : \beta = 1 : 1 : 0$ のときの結果を図 5(a) に示す．この場合，式 (8) は式 (3) と一致するため，図 5(a) は従来手法の結果 (図 1(a)) を線形多様体に射影したものになる．式 (7) から，PSNR 値は常に SRCNN による結果を上回るもの

表 1 実験環境

OS	Microsoft windows10 64 bit
GPU	Nvidia 2x GeForce GTX 1080 Ti
RAM	64.0 GB
Platform	Python 3.6 (64 bit)





図 5 式 (8) の一部のみを損失関数とした場合の提案手法の結果

の，図 1(a) にも存在していない新たな白飛びや黒飛びが発生してしまう．次に寄与率 $2 - \alpha : \alpha : \beta = 0 : 2 : 0$ のときの結果を図 5(b) に示す．これは，「高解像度画像 x_n と提案する出力結果 \hat{x}_n の二乗誤差」のみを損失関数としたことになる．この場合，白飛びや黒飛びは完全に除去されるが，ブロックノイズが発生し画像精度は大きく劣化してしまう．

寄与率を $2 - \alpha : \alpha : \beta = 1 : 1 : \beta$ とする． $\beta = 0.01$ と $\beta = 0.25$ のときの結果を図 5(c) と図 5(d) に示す．この場合，式 (8) は式 (4) と一致するため，図 5(c) と図 5(d) は，それぞれ図 3(b) と図 3(c) を線形多様体に射影したものになる．式 (7) から，PSNR 値は上昇するものの，図 3(b) や図 3(c) で少なくなっていた白飛びや黒飛びが再び出現していることが分かる．

寄与率を $2 - \alpha : \alpha : \beta = 1 : \lambda : 0$ ($\lambda > 1$) とする． $\lambda = 100$ と $\lambda = 1500$ のときの結果を図 5(e) と図 5(f) に示す． $\lambda = 1500$ のとき，白飛びや黒飛びが除去された良好な画像が得られる．

(注1) : URL: <http://www.image-net.org/>



(a) $2-\alpha:\alpha:\beta = 4:400:1$ (b) $2-\alpha:\alpha:\beta = 4:2000:1$



(c) $2-\alpha:\alpha:\beta = 4:4000:1$ (d) $2-\alpha:\alpha:\beta = 4:6000:1$

図6 式(8)を損失関数とした場合の提案手の結果

寄与率を $2-\alpha:\alpha:\beta = 1:\lambda:0.25$ ($\lambda > 1$) とする。 $\lambda = 100$ ($2-\alpha:\alpha:\beta = 4:400:1$) のとき、 $\lambda = 500$ ($2-\alpha:\alpha:\beta = 4:2000:1$) のとき、 $\lambda = 1000$ ($2-\alpha:\alpha:\beta = 4:4000:1$) のとき、 $\lambda = 1500$ ($2-\alpha:\alpha:\beta = 4:6000:1$) のときの結果を図6(a), 図6(b), 図6(c), 図6(d)に示す。どの値においても超解像結果は良好でほとんど差はないが、 $\lambda = 1500$ のときに、図5(f)より PSNR 値が僅かに高い超解像画像が生成された。

表2と表3は、双三次補間, SRCNN, 提案手法 ($2-\alpha:\alpha:\beta = 4:4:1$ と $2-\alpha:\alpha:\beta = 4:6000:1$ の場合) の超解像画像の PSNR と SSIM の値を示している。提案手法により, SRCNN に比べて PSNR は最大 0.28 [dB], 平均 0.12 [dB], SSIM は最大 0.036, 平均 0.010 向上した。図7に SRCNN と提案手法 ($2-\alpha:\alpha:\beta = 4:6000:1$) による超解像画像を示す。この図からも分かるように, 提案手法では白飛びや黒飛びのない高品質な超解像結果を安定して生成することができている。

5. おわりに

本論文では, 従来手法において学習時に観測値の情報が欠落している点を指摘し, 観測誤差を考慮した損失関数を提案した。まず, 従来手法で提案された損失関数に観測誤差を加えることで観測誤差も小さくするように CNN のパラメータを調整し, 学習を行った。提案手法ではさらに, テストデータの観測誤差を 0 にする為に, 出力層に直交射影層を追加した。従来手法の損失関数を観測誤差が 0 である空間内の成分と垂直な成分に分解した。観測誤差が 0 である空間内の成分の最小化が本質であり, その成分を強調する損失関数を用いた。この損失関数によって学習した CNN で超解像を行い, 射影した結果, 白飛びや黒飛びを除去し, さらに従来手法と比較して画像精度が高い結果を出力した。また, 超解像処理にかかる時間は一瞬であり,

表2 PSNR による画像評価

	双三次補間	SRCNN	提案 (4:4:1)	提案 (4:6000:1)
baby	30.59	31.12	31.30	31.36
bird	30.18	30.63	30.71	30.65
butterfly	28.86	29.53	29.60	29.63
head	32.30	32.42	32.59	32.36
woman	30.44	31.01	31.29	31.29

表3 SSIM による画像評価

	双三次補間	SRCNN	提案 (4:4:1)	提案 (4:6000:1)
baby	0.8295	0.8597	0.8500	0.8679
bird	0.8196	0.8232	0.8528	0.8589
butterfly	0.7459	0.8327	0.8354	0.8361
head	0.8445	0.8616	0.8651	0.8568
woman	0.8248	0.8642	0.8668	0.8701

極めて高速に行うことができる。これにより, 提案手法の有効性を示した。今後は, 近年注目を集めている敵対的生成ネットワーク [12], [13] に直交射影層を導入することで, 真の高解像度画像により類似している超解像画像の生成を目指す。

文 献

- [1] 奥富 正敏, 田中 正行, 竹島 秀則, 松本 信幸, “画像超解像処理技術の最新動向,” 電子情報通信学会誌, vol. 93, no. 8, pp. 693–698, 2010.
- [2] 大倉 直, 高橋 友和, 井手 一郎, 村瀬 洋, “超解像処理を用いた低解像度文字の認識,” 情報科学技術フォーラム講演論文集, vol. 7, no. 3, pp. 65–66, 2008.
- [3] B. Haurang, W. Wang, M. Bates, and X. Zhuang, “Three-dimensional super-resolution imaging by stochastic optical reconstruction microscopy,” *Science*, vol. 319, no. 5864, pp. 810–813, 2008.
- [4] 高木 幹雄, 下田 陽久, 画像解析ハンドブック. 東京大学出版会, 2004.
- [5] J. Yang, J. Wright, T. S. Huang, and Y. Ma, “Image super-resolution via sparse representation,” *IEEE Transactions on Image Processing*, vol. 19, no. 11, pp. 2861–2873, 2010.
- [6] M. Elad, *Sparse and Redundant Representations: From Theory to Applications in Signal and Image Processing*. New York, NY: Springer, 2010.
- [7] C. Dong, C. C. Loy, K. He, and X. Tang, “Image super-resolution using deep convolutional networks,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, no. 2, pp. 295–307, 2016.
- [8] C. Dong, C. C. Loy, and X. Tang, “Accelerating the super-resolution convolutional neural network,” in *Proc. ECCV*, 2016, pp. 391–407.
- [9] W. Shi, J. Caballero, F. Huszár, J. Totz, A. Aitken, R. Bishop, D. Ruecker, and Z. Wang, “Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network,” in *Proc. CVPR*, 2016, pp. 1874–1883.
- [10] D. P. Kingma and J. L. Ba, “Adam: A method for stochastic optimization,” in *Proc. ICLR*, 2015, 15 pages.
- [11] M. Bevilacqua, A. Roumy, C. Guillemot, and M. L. Alberi-Morel, “Low-complexity single-image super-resolution based on nonnegative neighbor embedding,” in *Proc. BMVC*, 2012, 10 pages.
- [12] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, “Generative adversarial nets,” in *Proc. NIPS*, 2014, pp. 2672–2680.
- [13] C. Ledig, L. Theis, F. Huszár, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz, Z. Wang, and W. Shi, “Photo-realistic single image super-resolution using a generative adversarial network,” in *Proc. CVPR*, 2017, pp. 105–114.



(a) 入力画像

(b) 目標画像

(c) 従来手法

(d) 提案手法

図 7 従来手法 (SRCNN) と提案手法 ($2 - \alpha : \alpha : \beta = 4 : 6000 : 1$) による超解像結果の比較